




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE ZÁKLADNÍCH ČÁSTÍ LIDSKÉHO MOZKU V MR DATECH

SEGMENTATION OF THE BASIC PARTS OF HUMAN BRAIN IN MR DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

PAVEL KLÁSEK

VEDOUcí PRÁCE

SUPERVISOR

Ing. MILOŠ MALÍNSKÝ

BRNO 2012



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

Student: Pavel Klásek

ID: 125038

Ročník: 3

Akademický rok: 2011/2012

NÁZEV TÉMATU:

Segmentace základních částí lidského mozku v MR datech

POKYNY PRO VYPRACOVÁNÍ:

1) Proved'te literární rešerši použití metod pro segmentaci MR obrazových dat. Zaměřte se na bílou a šedou hmotu mozkovou a CSF. Prostudujte možnosti komerčně dostupného software. 2) Diskutujte použitelnost výsledků segmentace. 3) Navrhněte metodu segmentace obrazů a uveďte možnosti, jak matematicky a vizuálně hodnotit výsledky ve srovnání s výsledky z komerčně dostupného softwaru. 4) Navrhněte řešení metody v programovém prostředí Matlab. 5) Proved'te hodnocení výsledků na reálných CT datech ve srovnání s výsledky programu FreeSurfer. 6) Proved'te diskusi získaných výsledků a zhodnoťte využitelnost řešení.

DOPORUČENÁ LITERATURA:

- [1] JAN, J. Medical Image Processing, Reconstruction and Restoration - Concepts and Methods. Boca Raton : CRC Press, Taylor and Francis, 2005. p. 760. ISBN: 0-8247-5849-8.
[2] SCHMANSKY, N. Articles - Free Surfer Wiki. FreeSurferWiki. [Online] August 8, 2011. [Cited: August 31, 2011.] <http://surfer.nmr.mgh.harvard.edu/fswiki/Articles>.

Termín zadání: 6.2.2012

Termín odevzdání: 25.5.2012

Vedoucí práce: Ing. Miloš Malínský

Konzultanti bakalářské práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Práce popisuje segmentační metody používané v souvislosti se zpracováním obrazových dat, z nichž vybírá a uskutečňuje metody vhodné k požadované aplikaci segmentace částí mozkové tkáně – regionově orientovanou metodu narůstání oblastí a hybridní algoritmus rozvodí. Zvolené techniky aplikuje na reálných souborech dat. Výsledky realizací předkládá a hodnotí ve srovnání s referenčními výsledky pokročilého softwarového nástroje FreeSurfer. Text uvádí také výčet softwaru, který se pro účel segmentace v neurologii uplatňuje.

KLÍČOVÁ SLOVA

Segmentace, mozek, bílá hmota, šedá hmota, mozkomíšní mok, magnetická rezonance, FreeSurfer, narůstání oblastí, rozvodí.

ABSTRACT

This work describes segmentation methods used in image data processing, from which there are selected and implemented suitable methods for solving the assignment of segmentation parts of human brain – region growing and watershed algorithm. Segmentation techniques are realized on real data sources. Final segmentation results are presented, compared and evaluated according to the advanced software FreeSurfer segmentation results. In addition there is a list of available software that can be applied for the purpose of neurological image segmentation.

KEYWORDS

Segmentation, brain, white matter, gray matter, cerebrospinal fluid, magnetic resonance, FreeSurfer, region growing, watershed.

KLÁSEK, P. *Segmentace základních částí lidského mozku v MR datech*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 50 s., 1 s. příloh. Vedoucí bakalářské práce Ing. Miloš Malínský.

Prohlášení

Prohlašuji, že svou bakalářskou práci na téma Segmentace základních částí lidského mozku v MR datech jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 24. května 2012

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Miloši Malínskému za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

Dále děkuji především své rodině a blízkým za morální podporu a pomoc během tvorby této práce a celé doby mého studia.

V Brně dne 24. května 2012

.....
podpis autora

OBSAH

SEZNAM OBRÁZKŮ	VII
SEZNAM TABULEK.....	VIII
ÚVOD.....	9
1 SEGMENTACE OBRAZU	11
2 METODY SEGMENTACE OBRAZU	12
2.1 SEGMENTACE NA ZÁKLADĚ PARAMETRICKÉHO VYJÁDŘENÍ	12
2.1.1 Segmentace podle intenzity	13
2.1.2 Segmentace na základě vektorových hodnot	14
2.2 REGIONOVĚ ORIENTOVANÁ SEGMENTACE	15
2.2.1 Segmentace narůstáním oblastí	15
2.2.2 Segmentace slučováním oblastí	16
2.2.3 Segmentace dělením a slučováním oblastí	16
2.3 SEGMENTACE NA ZÁKLADĚ HRANOVÉ REPREZENTACE.....	17
2.3.1 Hranice modifikací hranové reprezentace	17
2.3.2 Hranice podle Houghovy transformace.....	18
2.3.3 Segmentace sledováním hrany	18
2.3.4 Segmentace podle pružných a aktivních kontur	19
2.4 SEGMENTACE NA ZÁKLADĚ STATISTICKÝCH MODELŮ	20
2.4.1 Shluková analýza.....	20
2.5 HYBRIDNÍ METODY SEGMENTACE	21
2.5.1 Segmentace metodou rozvodí	21
2.6 METODY VYUŽÍVAJÍCÍ ZNALOSTÍ.....	22
2.6.1 Segmentace využitím atlasů TPM.....	23
3 DOSTUPNÝ SEGMENTAČNÍ SOFTWARE.....	24
3.1 3D SLICER.....	24
3.2 ANALYZE	24
3.3 EIKONA3D.....	25
3.4 FREESURFER	25
3.5 FSL.....	25
3.6 ITK	25
3.7 SPM.....	26
4 ROZDĚLENÍ MOZKU	27

4.1	ANATOMICKÉ STRUKTURY	27
4.2	ZÁKLADNÍ TKÁŇOVÉ STRUKTURY	28
4.2.1	Mozkomíšní mok.....	28
4.2.2	Bílá hmota mozková.....	28
4.2.3	Šedá hmota mozková	28
5	OBRAZOVÁ DATA	29
5.1	ZDROJOVÁ DATA	29
5.2	REFERENČNÍ DATA	29
6	REALIZACE SEGMENTAČNÍCH METOD.....	33
6.1	METODA NARŮSTÁNÍ OBLASTÍ	33
6.2	METODA ROZVODÍ.....	33
7	HODNOTÍCÍ METODY	35
7.1	MATEMATICKÉ HODNOCENÍ	35
7.1.1	Rozhodovací klasifikátory.....	35
7.1.2	Určení obsahu segmentů	37
7.2	VIZUÁLNÍ HODNOCENÍ.....	37
7.2.1	Překrytí obrazu jeho segmenty	37
7.2.2	Překrytí obrazu konturami segmentů	37
8	VÝSLEDKY A HODNOCENÍ.....	38
9	ZÁVĚR.....	44
	LITERATURA.....	46
	SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK	48
	PŘÍLOHY.....	50

SEZNAM OBRÁZKŮ

Obr. 2.1: Histogram tří objektů v obrazu: (vlevo) dostatečný rozestup intenzit, (vpravo) špatná rozeznatelnost vlivem splývání intenzit, podle [7]	13
Obr. 2.2: Definice čtyř a osmi-okolí obrazového bodu.....	15
Obr. 2.3: Představa částečně zaplavených povrchů intenzit obrazu, které jsou odděleny myšlenými hrázemi, podle [7].....	22
Obr. 4.1: Lidský mozek a jeho dělení, na základě [27].....	27
Obr. 4.2: Řez mozkovými hemisférami a jejími strukturami, bílou a šedou hmotou a mozkovými komorami, podle [27]	28
Obr. 5.1: Koronární řez zdrojovým a referenčním souborem	31
Obr. 6.1: Oblasti po aplikaci metody rozvodí	34
Obr. 8.1: Výsledky segmentace bílé hmoty mozkové na koronárním řezu dat MRI.....	41
Obr. 8.2: Výsledky segmentace šedé hmoty mozkové na koronárním řezu dat MRI.....	42
Obr. 8.3: Výsledky segmentace mozkomíšního moku na koronárním řezu dat MRI.....	43

SEZNAM TABULEK

Tab. 5.1: Snímací protokoly MR při pořízení obrazových dat.....	29
Tab. 5.2: Převodní tabulka mezi anatomickými strukturami a typem mozkové tkáně výstupních dat automatické segmentace programem FreeSurfer.....	31
Tab. 7.1: Kontingenční tabulka klasifikace obrazových bodů	36
Tab. 8.1: Kompletní srovnání výsledků segmentací prvního zdrojového souboru vůči referenčním výsledkům programu FreeSurfer	38
Tab. 8.2: Kompletní srovnání výsledků segmentací druhého zdrojového souboru vůči referenčním výsledkům programu FreeSurfer	39
Tab. 8.3 Celkové srovnání výsledků segmentací dalších zdrojových souborů vůči referenčním.....	40

ÚVOD

Mozek člověka obsahuje struktury, které mají na starosti různé úlohy, od zajištění základních životních funkcí po složité myšlenkové pochody. Zobrazování mozku magnetickou rezonancí (MRI) umožňuje vědcům a lékařům tyto struktury lokalizovat a dozvědět se více o dopadech jejich změn na funkci mozku. Na pokroku ve studiu strukturních změn mozku má svůj neodmyslitelný podíl také segmentace jeho obrazových dat do tří základních tkáňových struktur – bílé hmoty mozkové (WM), šedé hmoty mozkové (GM) a mozkomíšního moku (CSF). Vzhledem k množství dat vytvořených při vyšetření magnetickou rezonancí (MR) je takřka nemožné, aby byla segmentace prováděna pouze manuálně prostřednictvím zkušených odborníků. Proto jsou zaváděny různé poloautomatické či automatické metody segmentace, které mají za úkol člověku od této činnosti ulevit i přes případnou nižší přesnost segmentace, která se však stává objektivní.

Segmentací částí mozku lze odhalit postupující anatomické změny a abnormality mozkového vývoje, které souvisí s jeho zhoršenou funkcí a zdravotním stavem, např. Alzheimerovou chorobou, schizofrenií, demencí, onkologickým či jiným mozkovým onemocněním. Pro diagnostiku a léčbu mimořádností jeho vývoje je nutné rozdělit mozek do jednotlivých zájmových oblastí a ty kvantitativně měřit. Výsledky segmentace tkáňových struktur je možné použít v dalším stupni zpracování obrazu, kdy lze v jednotlivých segmentech přesněji vyhledat významné anatomické znaky či struktury a následně je označit, popisovat, měřit a porovnávat.

Použitelnost segmentace základních částí lidského mozku z obrazů MRI můžeme ilustrovat na příkladech lékařských aplikací a studií, konkrétně Evans et al. [1] používá segmentaci 3D obrazu k měření volumetrie (objemu) mozku – celkového intrakraniálního objemu, objemu jednotlivých struktur WM, GM, a CSF nebo měření kortikální tloušťky mezi povrchy WM a GM (*cortical thickness*). Výsledky této dlouhodobé studie umožnily stanovit normální vývin i vývojové abnormality dětského mozku. V práci Dale et al. [2] je zmíněn soubor procedur, které vedou k automatické 3D rekonstrukci topografického uspořádání povrchu kortikální oblasti, mezi něž patří segmentace obrazu. Z výsledků segmentace lze rovněž stanovit objemy tkáňových struktur, kortikální tloušťku, apod.

Charakteristikou specifických lokálních změn atrofie mozku v souvislosti s mírou raného rozvoje Alzheimerovy choroby se věnuje práce Sabancu et al. [3]. Po segmentaci obrazových dat programem FreeSurfer je měřen a sledován dlouhodobý úbytek kortikálního mozkového objemu. Obdobnou problematiku popisuje text Kuperberg et al. [4], který interpretuje místní poklesy tloušťky šedé hmoty mozkové kůry u pacientů s chronickou schizofrenií. S objemem GM pracuje také zpráva Sailer et al. [5], která potvrzuje změnu kortikální tloušťky u pacientů

postihnutých roztroušenou sklerózou. Podle rozsahu atrofie mozku je možné stanovit stádium průběhu onemocnění.

Nejen segmentací struktur WM, GM, a CSF, ale také označením a extrakcí nádorové tkáně a tumorů z multimodálních obrazových dat MRI a fMRI se zabývá práce Cai et al. [6]. K tomuto účelu využívá klasifikační techniku a trénovací obrazová data vzniklá z přesných manuálních segmentací. Klasifikátory slouží k tvorbě tkáňových pravděpodobnostních map (TPM) nesoucích informace o parametrech tumorů, což umožňuje jejich přesnou lokalizaci vedoucí k plánování léčby a operací.

Cílem samotné bakalářské práce je seznámit se s teorií zpracování obrazu, především s úkony souvisejícími s procesem obrazové segmentace a tyto poznatky převést do praktického řešení zadané problematiky rozdělení mozkové tkáně. Úvod do oblasti segmentace obrazu je uveden v první kapitole práce, na níž navazuje kapitola druhá popisující možnosti známých segmentačních metod, které jsou seřazeny do ucelenějších skupin podle svých vlastností a charakteru aplikace. Třetí kapitola poskytuje výčet dostupného programového vybavení s jeho možnými aplikacemi, především při práci s obrazovými daty MRI. Ve čtvrté kapitole lze pro lepší přehled nalézt krátký popis rozdělení lidského mozku společně s představením základních tkáňových struktur. Kapitola pátá informuje o zdrojových souborech, které jsou v práci použity a o úpravě referenčních dat. Popis realizovaných metod narůstání oblastí a rozvodů v prostředí MATLAB obsahuje kapitola šestá. Srovnávací metodika dosažených výsledků je představena v sedmé části práce, jejíž výsledky a přiložené obrazové výstupy jsou popsány a diskutovány v závěrečné kapitole práce.

1 SEGMENTACE OBRAZU

Vlivem množství oborů, které využívají obrazová data a různorodosti použití těchto dat, bylo navrženo množství postupů při jejich zpracování. Jedním ze základních kroků v průběhu analýzy obrazu je proces jeho segmentace, jenž rozděljuje obraz do nepřekrývajících se částí reprezentující konkrétní objekty, které se v něm vyskytují. Představou může být obraz MRI, kde je každý obrazový pixel, resp. objemový voxel, opatřen příslušným indexem segmentu, jenž jej odkazuje např. na tkáň kosterní, svalovou, mozkovou, na tekutinu atd., [7].

Segmentace nebývá při analýze obrazu používána sama o sobě, ale předchází jí metody předzpracování obrazu, jako odstranění nežádoucích struktur, filtrace obrazu, normalizace intenzity nebo geometrie obrazu. Stejně tak není segmentace konečným výsledkem, ale často vystupuje v dalších krocích zpracování obrazových dat.

Segmentaci obrazu v souvislosti s objekty v obrazu a spojitostmi mezi nimi rozlišujeme na dva typy:

- částečná segmentace – oblasti přímo nesouhlasí s objekty v obrazu,
- kompletní segmentace – oblasti odpovídají objektům obsaženým v obrazu.

K získání kompletní segmentace obrazu je často nutné použít výsledky částečné segmentace jako vstup do vyšší úrovně zpracování obrazu, [8].

Definice segmentace říká, že konkrétní segmentovaný obraz je konečná množina oblastí $\{R_1, R_2, \dots, R_S\}$, které jsou vzájemně disjunktní [7]:

$$R_i \cap R_j = \emptyset, \quad i \neq j \quad (1.1)$$

a pokrývají oblast obrazu úplně:

$$R = \bigcup_{i=1}^S R_i. \quad (1.2)$$

Existuje mnoho různých metod a postupů obrazové segmentace, které jsou aplikovány v závislosti na dané problematice a požadavcích, kterých je snaha dosáhnout. Tím lze volit vždy optimální prostředek segmentace.

2 METODY SEGMENTACE OBRAZU

Zřejmě nejstarší, realizačně nejjednodušší, avšak nejnamáhavější metodou segmentace obrazu je manuální segmentace. S rozvojem výpočetní techniky je tendence plně či částečně přenechat tento úkol právě na ni. V medicínských aplikacích segmentace obrazu, zejména v neurologii, hraje stále významnou roli lidský faktor, jakkoli mohou být výsledky poloautomatické či zcela automatické segmentace obrazu přesné, je zvláště v medicínských aplikacích segmentace třeba ověřit výsledky člověkem.

Obsahem této kapitoly je popis metod, které využívají zejména poloautomatickou segmentaci (člověk podněcuje žádané parametry). Některé z níže uvedených metod jsou aplikovány globálně na celý obraz, jiné je lepší aplikovat lokálně, pouze na předdefinované oblasti obrazu, kde mohou dosahovat lepších výsledků.

Základní segmentační přístupy můžeme na podle [8] rozdělit do tří nejzákladnějších skupin podle dominantních rysů, kterých využívají:

- segmentace na základě parametrů obrazových pixelů,
- regionově orientovaná segmentace,
- segmentace na základě hranové reprezentace.

Tyto základní skupiny metod je možné dle [9] rozšířit do dalších skupin, které se vyznačují použitím optimalizačních metod základních modelů, případně vnášejí do procesu segmentace znalostní údaje:

- statistické metody,
- hybridní metody,
- znalostní metody.

2.1 Segmentace na základě parametrického vyjádření


Segmentace na základě parametrického vyjádření odkazuje na pojem homogenity oblastí, tj. segment obrazu je považován za homogenní vzhledem k jeho charakteristickému parametru (jas, stupeň šedi, barva, textura). Tento druh segmentace má svá omezení vlivem nehomogenit při snímání obrazu. Spíše než s jedinou hodnotou parametru (intenzita jasu) je pracováno s rozpětím tohoto parametru (interval intenzity jasu), který se považuje za homogenní, [7].

2.1.1 Segmentace podle intenzity

Parametrem obrazové segmentace podle intenzity je jas. Uvedeme účinek dvojitého prahování, kdy pro každou třídu, která v segmentaci vystupuje, stanovíme horní a dolní mez intenzit – prahy intenzit l_u, l_d . Hodnoty uvnitř intervalu těchto prahů jsou považovány v dané třídě za homogenní. Prahy se nepřekrývají, ale často na sebe navazují. Dvojitě prahování použijeme v případech, kdy charakteristické intenzity v obrazu označují právě jednotlivé objekty. Z medicínských aplikací lze metodu dobře použít na obrazová data CT rentgenového zobrazení, díky charakteru výstupních dat této modality. Pro data z MRI se použití vlivem nestandardizovaných hodnot intenzit komplikuje. Transformace obrazu dvojitým prahováním odpovídá vztahu podle [8]:

$$g(i, j) = \begin{cases} 1 & \text{pro } l_d \leq f(i, j) \leq l_u \\ 0 & \text{pro } l_d > f(i, j) \cup f(i, j) > l_u, \end{cases} \quad (2.1)$$

kde f představuje vstupní obraz a g výstupní binární obraz s prahy l_u a l_d . Přídavkem dalších úrovní intenzit a prahových hodnot dosáhneme víceúrovňového prahování, [7].



Obr. 2.1: Histogram tří objektů v obrazu: (vlevo) dostatečný rozestup intenzit, (vpravo) špatná rozeznatelnost vlivem splývání intenzit, podle [7]

Stěžejním problémem metody je správné stanovení prahových hodnot. Prahy mohou být upraveny interaktivně po posouzení výsledku segmentace. Lepším způsobem je algoritmizace nastavení prahů podle histogramu obrazu. Tento postup lze použít pouze v případě dostatečného rozestupu úrovní jasů segmentovaných objektů (Obr. 2.1 vlevo). Meze intervalů jsou pak umístěny do lokálních minim hranic objektů v histogramu. V tomto případě očekáváme nízkou chybu v klasifikaci přechodových pixelů. Pokud vypadá histogram jako na Obr. 2.1 (vpravo), kde se částečně překrývají intenzity jednotlivých objektů obrazu, je algoritmizace hodnot prahů obtížná. V klasifikaci pixelů na přechodu intenzit může tímto

docházet k velkým chybám, které je třeba eliminovat, např. výpočtem pravděpodobnosti pro příslušnost dané intenzity do jedné ze tříd podle [7]:

$$P(B|A) = \int_{l_{dB}}^{l_{uB}} p(A)df, \quad P(A|B) = \int_{l_{dA}}^{l_{uA}=l_{uB}} p(B)df. \quad (2.2)$$

Jedno z nejlepších řešení problému nabízí metoda optimálního prahu, která vychází z představy histogramu jako váženého součtu dvou a více normálních rozdělání pravděpodobností výskytu intenzit v obrazu. Práh je nastaven jako nejbližší hodnota intenzity, která koresponduje s nejnižší pravděpodobností mezi maximy dvou či více normálních rozložení. Pokud známe počet distribucí v histogramu, můžeme aproximovat jejich tvary, např. pomocí Gaussových funkcí. V případě, že je histogram obrazu složen z více normálních rozložení, použijeme pro jejich aproximaci model, který minimalizuje rozdíly mezi modelovaným a původním histogramem obrazu na základě [8]:

$$h_{model}(g) = \sum_{i=1}^n a_i \cdot e^{\frac{-(g-\mu_i)^2}{2\sigma_i^2}}, \quad (2.3)$$

kde g je hodnota intenzity ze všech intenzit G histogramu, a_i značí vrchol Gaussovy funkce, μ_i je střední hodnota intenzit bodů a σ_i směrodatná odchylka rozložení intenzit. Optimální parametry Gaussova rozložení jsou stanoveny minimalizací přizpůsobovací funkce F dle [8]:

$$F = \sum_{g=0}^{N-1} (h_{model}(g) - h_{obraz}(g))^2, \quad (2.4)$$

kde N je maximální počet intenzit v obrazu, h_{model} a h_{obraz} jsou funkce modelovaného, resp. původního histogramu obrazu. Při řešení práce bylo využito prahování na základě empirického nastavení prahových hodnot jako součást použitých metod segmentace.


2.1.2 Segmentace na základě vektorových hodnot

O vektorových hodnotách obrazu můžeme mluvit v případě, kdy každý obrazový bod obrazu obsahuje více než jednu hodnotu intenzity – vektor intenzit. Příkladem je barevný obraz se třemi hodnotami intenzit barevných složek případně obraz se zřetelnou texturní informací. Segmentaci vektorových hodnot však není možné provádět pomocí 1D histogramu, jako v předchozím případě. Na vícerozměrná data je potřeba použít tzv. spojeného 2D histogramu (vícerozměrného histogramu), do kterého vstupují intenzity dvou obrazů. Spojený histogram prezentuje vztah mezi intenzitami odpovídajících míst obou obrazů, [7].

Segmentace vektorových hodnot je v současné době široce používána při zpracování multimodálních dat, která vznikají spojením zobrazovacích systémů jako CT a MR, fMRI, PET, aj. Pro segmentaci tkáňových struktur mozku ze zdrojových souborů dat tomografu MR tento postup nevyužijeme.

2.2 Regionově orientovaná segmentace

Regionově orientované techniky segmentace se zakládají obdobně na homogenitě oblastí, kterou je nutno definovat společnými parametry, jako např.: hodnotou úrovně šedi, barvou, texturou, tvarem, atd. Metody zde popsané vytvářejí segmenty přímo. Výhodou tedy je, že nehledají v obraze hrany, které jsou společně se šumem vyššími složkami frekvenčního spektra obrazu. V obrazech postižených šumem je vzhledem k lepším výsledkům výhodnější použití metod zaměřených na vlastnosti oblastí, [7].



Obr. 2.2: Definice čtyř a osmi-okolí obrazového bodu

2.2.1 Segmentace narůstáním oblastí

Princip metody narůstáním oblastí (*region growing*) je jednoduchý. Nejdříve se v obraze určí počáteční body, tzv. semínka, ze kterých se segment dále rozšiřuje. Tato semínka definují segmentovanou oblast svými vlastnostmi, které jsou v ní typické. Vlastnosti pixelů jsou dány parametrem p , nejčastěji intenzitou, lokálním průměrem či odchylkou. Pixelů v nejbližším okolí (čtyř nebo osmi-okolí na Obr. 2.2) jsou poté začleněny do daného regionu, pokud splňují určené kritérium homogenity, porovnají se tedy hodnoty parametrů dle [7]:

$$|p_s - p_j| \leq T, \quad (2.5)$$

kde p_s je referenční parametr počátečního bodu, p_j je parametr porovnávaného pixelu a T je rozhodovací úroveň. Obrazové body, které kritériu nevyhovují, nejsou do oblasti začleněny. Takto je postupně procházen celý obraz až do doby, kdy do oblastí nelze podle zadaného kritéria přidat další bod. Složitější může být volba parametru a umístění počátečních bodů, což lze provést manuálně.

Pokud se v obraze vyskytne kupříkladu pozvolná nehomogenita jasu, může být její účinek potlačen dynamickou úpravou srovnávacího procesu, kdy se kandidáti oblasti neporovnávají s parametrem počátečního bodu, ale okrajového bodu oblasti, případně střední hodnotou regionu a dalšími parametry, [7].

Pravidla počátečního rozdělení oblastí stejně jako kritéria jejich následného spojování jsou značně variabilní. Na výsledek segmentace může mít vliv pořadí, ve kterém jsou oblasti spojovány. Pro realizaci automatizované segmentace mozku do tkáňových struktur je předpokladem tuto metodu dobře využít.

2.2.2 Segmentace slučováním oblastí

Segmentace metodou slučování oblastí má obdobný průběh jako v případě metody narůstání oblastí. Na počátku segmentace jsou zvoleny malé oblasti, tvořeny nejlépe samostatnými pixely, které jsou považovány za homogenní. Nyní přichází na řadu porovnání dvou sousední oblastí a jejich spojení, pokud je splněno dané kritérium homogenity. Parametry kritéria homogenity mohou být definovány podobně jako v rovnici 2.5. Statický způsob definice kritéria vychází z podobnosti vybraného parametru, na základě [7]:

$$p_{i,m,n} \in \langle p_0 - \Delta p, p_0 + \Delta p \rangle, \quad (2.6)$$

kde p_0 , resp. p_i je střední hodnota parametru počáteční, resp. porovnávané oblasti a Δp je zvolená tolerance parametru. Takto získané výsledky jsou však totožné jako při použití metod parametrického vyjádření v části 2.1.

K dosažení lepších výsledků lze opět zavést dynamický parametr podobnosti oblastí, jež mají být spojeny. Může jím být třeba podobnost aktuálních středních hodnot, které se mění s postupem oblastí. Navíc je možné zavést slučování podle tzv. kritéria síly hranic mezi oblastmi, které pracuje s lokálními rozdíly mezi hraničními pixely umístěnými na obou stranách elementární hrany sousedních oblastí. Síla lokální hrany, která odděluje oblasti R_i a R_j , je pro každý k -tý pár pixelů dána absolutní hodnotou rozdílu hodnot zvoleného kritéria T . Za slabou je elementární hrana považována na základě [7]:

$$s_{i,j,k} \leq T_1, \quad (2.7)$$

jinak je pokládána za silnou. Celková síla hranice $S_{i,j}$, která je tvořena N pixely, je dána počtem silných hran N_s . Pro slabou hranici platí dle [7]:

$$S_{i,j} = \frac{N_s}{N} \leq T_2, \quad (2.8)$$

což má za následek rozpad hranice a sloučení obou oblastí, v opačném případě je hranice oblastí silná a je zachována.

2.2.3 Segmentace dělením a slučováním oblastí

Základní koncept první fáze této metody říká, že oblast obrazu, která není dle zvoleného kritéria homogenní, musí být rozdělena na menší oblasti (nižší úrovně). Proces dělení oblastí se opakuje na nehomogenních menších oblastech obrazu až do chvíle, kdy jsou konečné dílčí oblasti homogenní. Dělení nehomogenních oblastí obrazu probíhá nejčastěji na čtvrtiny.

Takto vzniklé kvadranty označují postup shora dolů, tzv. pyramidální reprezentaci, kterou je možno použít i jako jednoduchou kompresní metodu obrazových dat, [7].

Během fáze dělení oblastí je možné lokálně porovnávat nově vznikající kvadranty, které mohou obsahovat pixely podobných parametrů. Přilehlé dceřiné kvadranty lze při splnění kritéria homogenity okamžitě sloučit a sníží tak množství potomků jednotlivých oblastí. Lokálně slučovat lze nyní pouze kvadranty vzniklé v rámci jednoho dělení oblastí, [7].

Ve druhé fázi segmentační metody postupujeme opačně jako v předchozí části 2.2.2 slučováním všech homogenních oblastí dle zvoleného kritéria. Výsledky segmentace se předpokládají stejné při vynechání i při aplikaci lokálního slučování během dělení oblastí. Lze počítat se vznikem spíše pravoúhlých oblastí. Pro řešení zadání lze postup použít, avšak vykazuje jistou analogii k metodě narůstání oblastí.

2.3 Segmentace na základě hranové reprezentace

Segmentace podle hranové reprezentace obrazu obsahuje širokou skupinu hranových detektorů, které se snaží nalézt v obrazu hrany. Cílem metod hranové reprezentace je spojování samostatných hran do řetězců, které představují hranice obklopující vznikající segmenty. Vzhledem k detekci hrany jako místa s náhlou změnou či přerušením jasu obrazu, mohou výraznější nehomogenity jednotlivých oblastí zapříčinit vznik významných hran považovaných za hranice segmentů. Také tato metoda tak svým způsobem respektuje teorii homogenity segmentovaných oblastí, avšak ne tak silně jako u jiných metod. Detekované hranice oblastí by měly být uzavřené, spojitě a měly by být v obrazu dobře popsány a lokalizovány. Aplikací hranových detektorů se však setkáváme s příliš tlustými či tenkými, násobnými a nespojitými hranami, které často neodpovídají okrajům vlastních segmentů. Z tohoto důvodu je nezbytné upravit výstup obrazů předzpracovaných hranovými detektory, [7].

2.3.1 Hranice modifikací hranové reprezentace

Odpovídající hranice segmentovaných částí obrazů jsou získávány úpravou výstupních obrazů z hrubé hranové reprezentace. Modifikace obrazu umožňuje např.: ztenčení hran na ideální tloušťku jednoho pixelu, odstranění falešných hran, které vznikly vlivem šumu a neoznačují skutečné oblasti obrazu nebo spojování nespojitých hran příslušících hranici oblasti, aby byla spojitá a v rámci oblasti uzavřená. Dosáhnout toho, aby získané hranice ohraničovaly skutečné oblasti obrazu, není jednoduché, dá se k tomu však dospět předem danou znalostí o souvislostech v daném obrazu, [7].

Některé úpravy, jako ztenčování a spojování hran, je možné uskutečnit prostřednictvím morfologických transformací. Prvním krokem morfologických úprav hranové reprezentace je

očištění od hran, které jsou vlivem šumu v obrazu kratší než vlastní hrany, což provedeme odstraněním všech hran s délkou menší než zvolený limit. Další postup představuje ztenčování hran tzv. podmíněnou erozí, kdy je na obraz hrubé hranové reprezentace aplikováno několik maskových operátorů (až 8 pro různé směry). Každá z masek je postupně posouvána nad obrazem. Pokud odpovídají hodnoty binárního obrazu hodnotám masky nad ním, je pixel pod centrálním prvkem masky vynulován a získávána tenčí hrana. Pro spojování hran tzv. podmíněnou dilatací aplikujeme také až 8 masek. Ty jsou obdobně posouvány nad obrazem, ale při totožnosti hodnot obrazu a masky je obrazový pixel pod jejím centrálním prvkem nastaven tak, že jsou hrany spojeny. Tenké a spojitě hrany lze získat opakovanou aplikací maskových operátorů.

Reprezentaci vyjadřující absolutní hodnotu velikosti hranové reprezentace (sílu hrany) a její změnu na rozsahu původního obrazu lze nejjednodušeji vyjádřit aplikací diferenciálních gradientních operátorů prvního řádu. Absolutní hodnota gradientu je rovna [7]:

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2}, \quad (2.9)$$

kde $\partial f/\partial x$ vyjadřuje derivaci prvního řádu ve směru souřadnicové osy x , $\partial f/\partial y$ pak ve směru y . Upravit obraz gradientu z hlediska potlačení slabých hran vzniklých vlivem šumu lze jednoduše např. prahováním. Modifikace hranové reprezentace lze provést i jinými složitějšími a propracovanějšími metodami, např. metodou relaxace hran, která propojuje prvky ztenčování, čištění a spojování hran do jednoho celku. Základní algoritmus jejího použití je rovněž popsán v publikacích [7] a [8].

2.3.2 Hranice podle Houghovy transformace

Houghova transformace se uplatňuje při modifikaci hrubé hranové reprezentace v případě, kdy se v ní vyskytnou určité známé tvary (přímka, kruh, elipsa, čtverec atp.), které mohou být do jisté míry nepřesné, přerušené nebo jinak zkreslené. Množství parametrů popisujících hledaný tvar v obrazu definuje počet dimenzí parametrického prostoru, do kterého přenáší Houghova transformace hranovou reprezentaci obrazu. Nevýhodou metody je výpočetní náročnost spojená se složitostí hledaného tvaru a počtem neznámých v příslušných parametrických rovnicích. K rozdělení mozku do jednotlivých tkáňových struktur se nehodí, jelikož tyto struktury nejsou nijak pevně tvarově definované, [7].

2.3.3 Segmentace sledováním hrany

Metoda se vztahuje na hranovou reprezentaci obrazu s nespojitými či vícenásobnými hranicemi oblastí. Aplikaci podmiňuje přítomnost vektoru pro každý pixel hranové reprezentace, který obsahuje informace o binárním údaji (1 pro existenci hrany, jinak 0),

intenzitě a směru hrany. Intenzitu a směr hran je možné získat prostřednictvím gradientních hranových detektorů (viz. 2.3.1). Důležitým aspektem je správný výběr počátečních bodů, jinak dochází ke sledování falešné hrany. Postup lze doplnit o upřednostněný výběr hran dle jejich známých parametrů. K postupu sledování hrany od počátečního bodu se volí rozměr okolí, tedy čtyř nebo osmi-okolí (Obr. 2.2) a definuje se podobnost okolních pixelů, [7].

Po volbě počátečního pixelu hranice je z jeho okolí vybrán jeden bod, který má nejmenší hodnotu rozdílu vektorových parametrů srovnávaných bodů. Tímto je počátečnímu bodu nejpodobnější a stane se novým pixelu hranice. Hledání nejpodobnějšího pixelu se pro nejnovější body hranice opakuje do chvíle uzavření hraniční křivky, dosažení okrajů obrazu, neexistence nových okolních pixelů, nebo pokud body nesplňují požadavek míry podobnosti. Sledování hrany pak končí, případně je zvolen nový počáteční hranový pixel, [7].

2.3.4 Segmentace podle pružných a aktivních kontur

Metody označované jako pružné kontury mají za cíl najít hranice oblastí z jejich hrubé hranové reprezentace na základě skutečného obsahu obrazu. Jedná se o pokročilé metody detekce hran a využívány jsou hlavně při výskytu specifického šumu, který při jiných postupech způsobuje detekci falešných obrysů. Pro řešení zadání není aplikace zde uvedených metod příliš vhodná vzhledem k velké členitosti a variabilitě tkáňových struktur v obrazech MRI. Složitost realizace metod je poměrně vysoká s přihlédnutím k nutnosti jejich proměnlivého počátečního zavádění, [7].

Aktivní kontury

Metoda se vyznačuje tvarováním kontur postupně ke hraně objektu v obrazu. Obrys aktivní kontury se deformuje přímo vlivem různých obrazových sil, které ovlivňují její výsledný tvar. Limitem metody se stává vznik artefaktů při prudkých změnách hranic objektů, což je možné odstranit obměnou algoritmu. Počáteční konturu je nutné inicializovat manuálně nebo na základě znalostí o tvaru a poloze objektů, [9].

Level-set

Postup patří do skupiny geometrických pružných kontur. Princip metody je podobný jako v případě aktivních kontur, ale s tím rozdílem, že deformace tvaru křivky se provádí nepřímo prostřednictvím vícerozměrné funkce level-set. Funkce udává každému bodu v rovině jeho výšku nad nulovou hladinou. Tím vzniká povrch funkce, která se postupně adaptuje danému objektu. Prvotní postup je volen obdobně jako v případě aktivních kontur, oproti níž dosahuje metoda level-set lepších výsledků zejména při výskytu složitější tvarů předmětů, [9].

2.4 Segmentace na základě statistických modelů

Prvotním krokem segmentace některým statistickým modelem je uskutečnění statistické analýzy obrazových dat. Vstupním parametrem analýzy je nejčastěji intenzita pixelů. Do této skupiny metod je tak možné zařadit již popisovanou metodu segmentace podle intenzity (část 2.1.1). Vyspělými statistickými metodami lze dosáhnout segmentace strukturních parametrů obrazu.

2.4.1 Shluková analýza

Segmentace metodou shlukové analýzy spočívá ve vytvoření podmnožin objektů (shluků) v obrazu, které se utvářejí na základě podobnosti či rozdílnosti vlastností mezi prvky jednotlivých shluků podle zvolených parametrů. Základní princip metody je závislý na výsledcích měření mezi všemi obrazovými body obrazu – každý pixel nese vektor výsledků těchto měření vůči ostatním. Parametry měření jsou např. barevné složky pixelů, vlastnosti okolí pixelů (střední hodnota intenzity, rozptyl) apod., [9].

Po zisku matice dat měření atributů objektů (intenzit pixelů) je často prováděna standardizace těchto dat. Standardizace je volitelným krokem, který přináší snížení vlivu širokých rozsahů hodnot atributů. Hojně je používána standardizace originálních atributů x na standardizované atributy z podle [10]:

$$z_{ij} = \frac{x_{ij} - \mu_i}{\sigma_i}, \quad (2.10)$$

kde indexy i a j značí daný atribut, resp. objekt, μ_i je střední hodnota atributu a σ_i jeho směrodatná odchylka. Nové atributy mají střední hodnotu rovnu 0 a směrodatnou odchylku 1.

Dalším postupem je kvantitativní výpočet matice podobností mezi jednotlivými páry objektů, ať už z původní nebo standardizované matice atributů. Nejčastěji se kritériem podobnosti stávají metriky na základě geometrického modelu dat, např. výpočet Euklidovské vzdálenosti mezi atributy. Pro n atributů je pro každé dva body (r, s) tato vzdálenost definována [10]:

$$e_{rs} = \sqrt{\sum_{i=1}^n (x_{ri} - x_{si})^2}. \quad (2.11)$$

Existují však i jiné metriky, např. výpočet Manhattanské vzdálenosti, Minkowského vzdálenosti, apod. Na řadu pak přichází samotné shlukování objektů dle vypočtených parametrů, které se dělí na hierarchické a nehierarchické metody shlukování, [10].

K-means algoritmus

Mezi nejznámější nehierarchické metody shlukové analýzy se řadí MacQueenova metoda známá jako k-means algoritmus. Jeho princip spočívá v klasifikaci objektů do konečného počtu shluků. Každý objekt je přiřazen shluku, k jehož středu má nejmenší vzdálenost. Středů shluků a jejich hodnoty jsou označovány jako centroidy. Prvotní centroidy je nutné stanovit, stejně tak je třeba na začátku algoritmu zadat počet shluků korespondující s celkovým počtem objektů v obraze.

Klasifikace objektů do příslušného shluku je výsledkem minimalizace kritéria (např. Euklidovské vzdálenosti) mezi objekty vůči všem centroidům. Poté následuje přepočítání střední hodnoty v daných shlucích ze všech k nim přiřazených bodů. Proces klasifikace objektů a přepočítávání středních hodnot se opakuje. Cílem je dosažení co nejmenších rozdílů parametrů objektů uvnitř každého shluku podle [10]:

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} (x_j - \mu_i)^2, \quad (2.12)$$

kde k udává počet shluků S_i a μ_i je průměr všech hodnot bodů x_j v daném shluku S_i . Princip této metody lze použít k segmentaci základních mozkových struktur WM, GM a CSF.

2.5 Hybridní metody segmentace


Zde je uvedena segmentační metoda, která využívají kombinace principů již zmíněných metod. Pro úplnost není zařazena k dílčím metodám, ale je představena samostatně. Jedná se o segmentaci algoritmem rozvodí.

2.5.1 Segmentace metodou rozvodí

Segmentace metodou rozvodí (*watershed*) je technikou, ležící na pomezí metod se zaměřením na homogenitu oblastí a hranovou analýzu obrazu. Metoda rozvodí bere jako segmenty oblasti, které tvoří okolí každého lokálního minima parametru obrazu (jas). Označení metody vychází z podobností povrchových intenzit obrazu s topografickými výškovými modely. Parametrický obraz je tak chápán jako reliéf, na jehož povrchu jsou rozpoznávána lokální minima, která jsou označována jako reprezentace samostatných segmentů. Při představě intenzity obrazu jako reliéfu je definován pojem povodí jako oblast, která přísluší lokálnímu minimu, k němuž směřuje podél nejstrmější cesty tok vodních kapek. Pojem rozvodí definuje hranice segmentů (jednotlivých povodí), [7].

Princip výpočetní metody demonstrujeme na představě vody, která postupně zaplavuje reliéf od nejnižších hodnot intenzit obrazu, čímž vytváří v jednotlivých povodích homogenní oblasti. Aby bylo možno dosáhnout zvedáním hladiny nejvyššího bodu reliéfu, aniž by se

jednotlivá povodí spojíla dohromady, jsou na hřebeny obklopující lokální povodí umístěny hráze (Obr. 2.3), které udávají hranice mezi segmenty (rozvodí), [7].



Obr. 2.3: Představa částečně zaplavených povrchů intenzit obrazu, které jsou odděleny myšlenými hrázemi, podle [7]

Algoritmus segmentace metodou rozvodí spočívá ve vzestupném uspořádání pixelů parametrického obrazu podle zvoleného parametru (intenzity), včetně jejich souřadnic. Následně je proveden postupný výběr pixelů, jejich označení štítkem příslušné oblasti (úrovně) a prohledání jejich bezprostředního osmi-okolí. Každý neoznačený pixel úrovně k od nejnižší po maximální dle principu zaplavení obrazu ($k = 0$ až k_{max}):

- je označen stejným štítkem, pokud je v jeho osmi-okolí označen jeden nebo více pixelů stejné oblasti,
- je označen jako hraniční, jsou-li v jeho osmi-okolí dva nebo více různě označených pixelů,
- zůstává neurčený, pokud se v jeho osmi-okolí nevyskytuje žádný označený pixel.

Na neoznačené oblasti či obrazové body úrovně k se provádí test konektivity. Pokud tyto oblasti přiléhají k označeným oblastem, jsou pixely určeny podle nejbližší označené oblasti. Mohou být označeny podle úrovně intenzity samy o sobě. Oblasti, které zůstávají neoznačeny a nemohou být propojeny s některým z existujících povodí, jsou definovány jako samostatné oblasti – nová povodí, [7]. Metoda se k realizaci zadání dá dobře aplikovat.

2.6 Metody využívající znalostí

Do této kategorie se řadí metody, které pracují se známými soubory vlastností, jež jsou typické pro segmentované objekty (tvar, barva, struktura, apod.). Vlastnosti jsou sdružovány v atlasech předloh segmentovaných objektů a jejich modelech. Při samotné segmentaci jsou

porovnávány hledané objekty se známými objekty atlasů, které jsou navíc často různě transformovány. Atlasy známých modelů objektů mohou být vytvářeny ze souborů trénovacích dat, především jsou ale získávány na základě výsledků manuálních segmentací vzniklých zkušeností člověka, [9].

2.6.1 Segmentace využitím atlasů TPM

Atlasy tkáňových pravděpodobnostních map (TPM) jsou tvořeny spojením většinou ručně získaných klasifikací obrazů z několika objektů. TPM vznikají ve stereotaktickém prostoru a vyjadřují odhady pravděpodobností výskytu voxelů jednotlivých struktur (GM, WM a CSF) v segmentovaném obrazu. V mnoha případech vyžaduje použití atlasů odlišný postup jak pro registraci obrazů, tak pro jejich následnou segmentaci. Cílem je plně automatická registrace a segmentace. Praktické využití TPM se dá nalézt právě při úkolu segmentace částí mozku, především v aplikacích sofistikovaných programových nástrojů (více v kap. 3). Mnohdy je nutno využít poloautomatických metod s ručně definovanými orientačními body, které omezí vznikající deformace a zvýší přesnost segmentace, zejména v kortikálních oblastech, mezi nimiž existuje vysoká variabilita, [17].

3 DOSTUPNÝ SEGMENTAČNÍ SOFTWARE

Proces segmentace má celou řadu aplikací v každodenním životě a má hluboký význam zejména na poli lékařské zobrazovací techniky – tomografií CT či MR. Samotný přístroj však poskytuje pouze data, ze kterých je nutné získat potřebné informace o sledovaných parametrech. Proto je třeba pokračovat ve vývoji počítačových aplikací, které dokáží zprostředkovat informace lepší a čistší, či naopak komplexnější. Tato část práce se tak věnuje krátkému výčtu programového vybavení, které lze použít pro práci s obrazovými daty MRI. Většina zmíněných nástrojů vznikla dlouhodobým vývojem a spoluprací vědeckých pracovišť lékařského a technického zaměření. Výběr popisovaného segmentačního softwaru proběhl na základě obsahu *Internet Analysis Tools Registry* (IATR) [11] při *Center for Morphometric Analysis* Všeobecné nemocnice v Massachusetts (MGH), kde lze nalézt informace o širokém seznamu nástrojů ke zpracování a analýze nejen medicínských obrazových dat. Podobné služby jako IATR nabízí také webové stránky *Neuroimaging Informatics Tools and Resources Clearinghouse* [12], které obsahují přehledné dělení dostupného softwaru vzhledem k druhu jeho použití a podporovaným funkcím.

3.1 3D Slicer

3D Slicer je volně dostupný open source software, který vznikl vývojem Laboratoře umělé inteligence (AIL) Massachusettského technologického institutu (MIT) a Laboratoře chirurgického plánování (SPL) při bostonské *Birmingham and Women's Hospital*. Mezi funkce tohoto softwaru patří segmentace, registrace nebo 3D zobrazení multimodálních obrazových dat (MRI, CT, PET, digitální mikroskopie, aj.), stejně jako analýza obrazů ze zobrazení tenzoru difuze (DTI) nebo fMRI. Samotná segmentace obrazu probíhá manuálně, poloautomatickými prostředky (prahování, morfologické operace) či automaticky. 3D Slicer nabízí široce rozšířené nástrojové sady ITK a VTK, [13].

3.2 Analýze

Komerční software pro analýzu obrazu byl vyvinut prostřednictvím *Biomedical Imaging Resource* při *Mayo Clinic* se sídlem v Rochesteru. Vlastní knihovna modulů dovoluje programu provádět segmentace obrazových dat na základě metod prahování, 2D či 3D narůstání oblastí, automatické detekce hran, aplikací morfologických operátorů nebo statistickými klasifikačními metodami. Software dovoluje práci zejména s obrazovými daty MRI, CT, SPECT, PET, ultrazvuku a digitální mikroskopie, [14].

3.3 EIKONA3D

Společnost *Alpha Tec Ltd.* stojí za vývojem softwaru EIKONA3D. Segmentaci 3D obrazu lze provést zejména regionově orientovanými metodami, jako jsou narůstání oblastí, slučování oblastí a dělení a slučování oblastí, ale také jednoduchým prahováním. Software umožňuje práci s obrazovými daty 3D mikroskopie, MRI a CT, [15].

3.4 FreeSurfer

FreeSurfer je open source softwarový balík, jehož vývoj probíhá v *Athinoula A. Martinos Center for Biomedical Imaging* [16], pracovišti MIT při MGH. Segmentaci mozku, tedy odstranění lebky a dalších nemozkových tkání, provádí FreeSurfer poloautomaticky prostřednictvím metody rozvodí. Tuto metodu používá rovněž ke stanovení hodnot intenzit objemových voxelů pro všechny tři mozkové struktury (WM, GM a CSF), jejichž vlastní segmentaci provádí automaticky na základě atlasů TPM. Software FreeSurfer pracuje konkrétně s Talairachovými anatomickými atlasy, [17]. Vstupní obrazová data MRI jsou tak rozdělena na segmenty odpovídající pravděpodobnostním mapám. Úpravy při odstraňování chyb segmentace lze v programu provádět manuálně. Software nabízí možnost rekonstrukce struktury mozkové kůry z tomografických řezů a překrytí toho modelu daty z fMRI nebo EEG. Aktuální verze nese označení 5.1.0, [18] a [19].

3.5 FSL

Software FSL byl vyvinut v *Center for Functional Magnetic Resonance Imaging of the Brain* při Oxfordské univerzitě. Obsahuje nástroje pro analýzu dat z fMRI, strukturální MRI a DTI. Segmentace částí mozku je realizována, obdobně jako pro FreeSurfer, na základě hodnot jednotlivých voxelů některého z pravděpodobnostních atlasů, např. *Harvard-Oxford Cortical and subcortical structural atlases* nebo *MNI structural atlases*, [21]. FSL umožňuje také segmentaci multispektrálních dat. Dostupný je volně v nejnovější verzi 4.1.9, [19] a [20].

3.6 ITK

Programová knihovna ITK (*Insight Segmentation and Registration Toolkit*) byla vytvořena společně s VTK (*Visualization Toolkit*) díky *United States National Library of Medicine*. Vývoj těchto volně dostupných knihoven s otevřeným zdrojovým kódem zajišťuje společnost *Kitware*. Nástroje knihovny ITK jsou často zařazeny do jiných programových balíčků analyzujících obrazová data (viz kap. 3.1). Jednotlivé moduly knihoven jsou sestaveny do bloků, ze kterých lze vytvořit aplikace pro segmentaci či registraci obrazových dat. Samotné

segmentační moduly zahrnují řadu nižších i vyšších metod segmentace, např. algoritmus rozvodí a narůstání oblastí, resp. segmentaci metodami level-set, deformovatelnými modely nebo znalostními algoritmy, [22], [23], [24].

3.7 SPM

Statistical Parametric Mapping (SPM) je open source software vytvořen při *Wellcome Trust Centre for Neuroimaging, University College London*. SPM je v podstatě sadou funkcí vyvinutou pro implementaci v programovém prostředí MATLAB. Software uplatňuje analogický postup segmentace struktur WM, GM a CSF jako FreeSurfer a FSL. Rozdíl tvoří zdroj upravených TPM, v případě SPM se jedná o *ICBM Tissue Probabilistic Atlases*, [19], [25], [26].


4 ROZDĚLENÍ MOZKU

Na tomto místě je uveden zjednodušený popis anatomického rozdělení lidského mozku do jeho nejzákladnějších částí. Také jsou krátce charakterizovány podstatné tkáňové struktury mozku (Obr. 4.2). Segmentace anatomických struktur programem FreeSurfer je popsána v části 5.2.

4.1 Anatomické struktury

Lidský mozek představuje orgán řídicího a organizačního centra centrální nervové soustavy (CNS). Na Obr. 4.1 jsou znázorněny hlavní anatomické části mozku, kterými jsou:

- prosencephalon (přední mozek), dělí se na:
 - telencephalon (koncový mozek),
 - diencephalon (mezimozek),
- mesencephalon (střední mozek),
- rhombencephalon (zadní mozek), obsahující:
 - metencephalon (mozeček),
 - myelencephalon (míšň mozek).




Obr. 4.1: Lidský mozek a jeho dělení, na základě [27]

4.2 Základní tkáňové struktury

4.2.1 Mozkomíšní mok

Mozkomíšní mok (CSF) je tekutina tvořící vnitřní výplň mozkových dutin – komorový systém, která se dostává do subarachnoidálního prostoru, kde je zpětně resorbována v arachnoidálních klcích, odkud putuje do žilního systému a lymfatických cév účinkem tlakového gradientu, [28].



Obr. 4.2: Řez mozkovými hemisférami a jejich strukturami, bílou a šedou hmotou a mozkovými komorami, podle [27]

4.2.2 Bílá hmota mozková

Struktura bílé hmoty mozkové (WM) neobsahuje žádné neurony, ale pouze jejich výběžky (axony) a neurogliové buňky, které tvoří strukturu a zajišťují výživu a regeneraci nervové tkáně. Příčinou světlé barvy WM je přítomnost myelinu tvořící lipoproteinový obal výběžků nervových buněk. Každé nervové vlákno má několik výběžků, jejichž funkcí je přenos informací uvnitř mozkových hemisfér, [29].

4.2.3 Šedá hmota mozková

Většinu šedé hmoty mozkové (GM) tvoří těla nervových buněk s nízkým obsahem lipidů – neurony. Struktury šedé hmoty jsou tmavšího zbarvení a navzájem se liší obsahem myelinu, kde nejméně je ho v mozkové kůře, více pak v thalamu a bazálních gangliích, [29].

5 OBRAZOVÁ DATA

5.1 Zdrojová data

Datové soubory, které jsou v práci použity, se skládají z 3D T1-vážených obrazů MR. Akviziční matice obrazů dosahuje rozměrů $256 \times 256 \times 256$ voxelů. Soubory pochází ze série snímků starších osob zúčastněných při studii *Kognitivní stárnutí*, [30] a [31]. Nastavení snímacích protokolů MR je popsáno v Tab. 5.1.

Multimodální akvizice dat byla provedena přístrojem 1,5 T GE Sigma Echo Speed Scanner, umístěným v Laboratoři MR *Haralds plass Deaconess Hospital* v Bergenu, za použití standardních osmi-kanálových hlavových cívek. Data byla poskytnuta prostřednictvím *Neuroinformatics and Image Analysis Laboratory*, působiště *Neuroscience Research Group* při Ústavu biomedicíny Univerzity v Bergenu.

	Cyklus	Parametry pulzní sekvence
1	Lokalizační 2D	TR/TE = 7,8[ms]/1,7[ms]/30[°]; voxel: $1,0 \times 1,0 \times 5,0$ [mm ³]; 3 [imgs]
2	Ax PD/T2 2D FSE	TR/TE1/TE2/FA = 3840/12,1/84,9/90; voxel: $0,94 \times 0,94 \times 4,0$; 52
3	Sa T1 3D FSPGR	TR/TE/TI/FA = 9.45/2.41/450/7; voxel: $0,94 \times 0,94 \times 1,40$; 124
4	Sa T1 3D FSPGR	(jako v 3, zlepšení SNR pro segmentaci softwarem FreeSurfer)
5	Sa T1 3D FSPGR	TR/TE/TI/FA = 9,11/1,77/450/7; voxel: $0,94 \times 0,94 \times 1,40$; 124
6	Sa T1 3D FSPGR	(jako v 3, zlepšení SNR pro segmentaci softwarem FreeSurfer)

Tab. 5.1: Snímací protokoly MR při pořízení obrazových dat

Zdrojová data byla předzpracována programem FreeSurfer (verze 5.0.0) odstraněním lebečních struktur a nemozkových tkání. Na data byla aplikována normalizace intenzity signálu a také geometrická normalizace ($0,94 \times 0,94 \times 1,4$) do Talairachova stereotaktického prostoru ($1,0 \times 1,0 \times 1,0$). Koronární řez zdrojovým souborem je předložen na Obr. 5.1 c).

5.2 Referenční data


Vlastní výsledky segmentace obrazových dat mozkových struktur jsou v práci srovnávány s daty, která jsou výstupem podrobného automatického rozčlenění mozku do jeho anatomických struktur (Obr. 5.1 a). Před dalším postupem a realizací segmentačních metod bylo nutné správně transformovat tato data na soubory tkáňových struktur bílé a šedé hmoty mozkové a mozkomíšního moku. Na základě seznamu segmentovaných struktur softwaru

FreeSurfer [18] společně s rozdělením některých z těchto struktur na základě práce [19] byla zformována převodní tabulka (Tab. 5.2) mezi anatomickými strukturami vyskytujícími se ve zdrojových souborech a strukturami WM, GM a CSF. Výsledek transformace mozkových struktur lze vidět na Obr. 5.1 b).


Index	Typ tkáně	Objekt segmentu	Index	Typ tkáně	Objekt segmentu
1	CSF	Left-Cerebral-Exterior	47	GM	Right-Cerebellum-Cortex
2	WM	Left-Cerebral-White-Matter	48	GM	Right-Thalamus
3	GM	Left-Cerebral-Cortex	49	GM	Right-Thalamus-Proper
4	CSF	Left-Lateral-Ventricle	50	GM	Right-Caudate
5	CSF	Left-Inf-Lat-Vent	51	GM	Right-Putamen
7	WM	Left-Cerebellum-White-Matter	52	GM	Right-Pallidum
8	GM	Left-Cerebellum-Cortex	53	GM	Right-Hippocampus
9	GM	Left-Thalamus	54	GM	Right-Amygdala
10	GM	Left-Thalamus-Proper	58	GM	Right-Accumbens-area
11	WM	Left-Caudate	60	GM	Right-VentralDC
12	GM	Left-Putamen	63	CSF	Right-choroid-plexus
13	GM	Left-Pallidum	72	CSF	5th-Ventricle
14	CSF	3rd-Ventricle	75	CSF	Left-Lateral-Ventricles
15	CSF	4rd-Ventricle	76	CSF	Right-Lateral-Ventricles
16	WM	Brain-Stem	77	WM	WM-hypointensities
17	GM	Left-Hippocampus	78	WM	Left-WM-hypointensities
18	GM	Left-Amygdala	79	WM	Right-WM-hypointensities
24	CSF	CSF	80	CSF	non-WM-hypointensities
26	GM	Left-Accumbens-area	81	CSF	Left-non-WM-hypointensities
28	GM	Left-VentralDC	82	CSF	Right-non-WM-hypointensities
31	CSF	Left-choroid-plexus	85	WM	Optic-Chiasm
40	CSF	Right-Cerebral-Exterior	251	WM	CC_Posterior

41	WM	Right-Cerebral-White-Matter	252	WM	CC_Mid_Posterior
42	GM	Right-Cerebral-Cortex	253	WM	CC_Central
43	CSF	Right-Cerebral-Cortex	254	WM	CC_Mid_Anterior
44	CSF	Right-Inf-Lat-Vent	255	WM	CC_Anterior
46	WM	Right-Cerebellum-White-Matter			

Tab. 5.2: Převodní tabulka mezi anatomickými strukturami a typem mozkové tkáně výstupních dat automatické segmentace programem FreeSurfer



a) surová segmentace anatomických struktur programu FreeSurfer (pseudobarvení)



b) tkáňové struktury WM (oranžově), GM (žlutě) a CSF (červeně)



c) koronární řez zdrojovým obrazem MRI

Obr. 5.1: Koronární řez zdrojovým a referenčním souborem

Problém při určování tkáňových struktur nastal pro mozkový kmen, který vykazuje vlastnosti WM i GM. Nakonec bylo zvoleno jeho označení jako bílá hmota. Uvedené rozdělení se snaží co nejvíce přiblížit reálnému rozložení tkáňových struktur, avšak i zde se

mohou vyskytnout chyby. Pro účel této práce platí získané obrazy tkáňových struktur jako zlatý standard při následném srovnávání s dosaženými výsledky vlastních segmentací.

6 REALIZACE SEGMENTAČNÍCH METOD

V této části práce jsou popsány zvolené segmentační metody, jejichž provedení bylo vytvořeno v programovém prostředí MATLAB ve verzi 7.12.0. Vzhledem k povaze obrazových dat, zadání práce a požadovaným obrazovým výstupům byla uskutečněna segmentace na základě narůstání oblastí a segmentace metodou rozvodí. Podrobný popis realizace metod je uveden ve zdrojových kódech přiložených na nosiči.

6.1 Metoda narůstání oblastí

Jak již bylo uvedeno v kapitole 2.2.1, princip metody narůstání oblastí není složitý. Hlavní problém správného rozdělení oblastí však tkví v určení počátečních bodů segmentovaných oblastí. Pro tuto práci bylo zvoleno hledání semínek oblastí na základě rozdělení intenzit ve zdrojovém obrazu. Z histogramu tak byly empiricky určeny intervaly intenzit pro hledané tkáňové struktury WM, GM a CSF. Toto řešení je možné použít v souvislosti s akvizicí snímků na jednom tomografu MR a jejich identickým předzpracováním pomocí softwaru FreeSurfer (normalizací intenzity v celém rozsahu souborů aj., viz. část 5.1). V jednotlivých intervalech jsou hledány intenzity s maximálním zastoupením pixelů v obrazu, které jsou označeny jako intenzity startovacích bodů.

Pro každé nalezené semínko dané intenzity v obrazu probíhá iterativně vlastní proces narůstání oblastí do okolí semínka a dalších hraničních bodů (osmi okolí), dokud jsou ve zdrojovém obrazu k dispozici semínka. Při rozrůstání oblasti o nové body je přepočítávána její střední hodnota, která je srovnávána se stanoveným kritériem přiřazení pixelu do oblasti dle prahu rozdílu intenzit. Všechny body získané oblastí jsou vyloučeny ze zdrojového obrazu, čímž je redukován počáteční počet startovacích bodů, počet proběhnutých iterací a čas nutný k výpočtu. Při realizaci této metody není nutností zdrojový obraz výrazně upravovat, jelikož hranice mezi segmenty jsou dostatečně silné. Testování odolnosti metody vůči aditivnímu šumu a filtraci obrazu mediánovým filtrem však způsobilo snížení rozdílů intenzit mezi jednotlivými tkáňovými oblastmi a rozšíření segmentů mimo zamýšlenou oblast. Tento jev by si vyžadoval adaptivní změnu nastavení prahu společně se zvýrazněním potlačených hran v obrazu.

6.2 Metoda rozvodí

Jak bylo zmíněno v části 2.5.1, leží tato metoda na pomezí metod hranové analýzy a homogenity oblastí. Před samotnou aplikací algoritmu rozvodí na zdrojový obraz je tak nezbytná jeho úprava, aby se zabránilo fenoménu přílišného počtu segmentů obrazu


(*oversegmentation*). V práci jsou vyzkoušeny dva způsoby předzpracování obrazu pro tuto metodu.

Prvním z nich je tvorba gradientního obrazu pomocí detekce hran (část 2.3.1). Pro hranovou detekci byl vybrán Sobelův hranový operátor založený na první derivaci, který dává větší důraz centrálnímu bodu než např. operátor Prewittové. Operátory první derivace zároveň nevykazují takovou citlivost na přítomnost šumu v obrazu, jako operátory druhé derivace (Laplacián) a jejich užití je jednodušší. Sobelův operátor slouží k lokalizaci hran v horizontálním i vertikálním směru. Následně je vypočtena absolutní hodnota gradientu podle rovnice (2.9). Posledním krokem před aplikací algoritmu rozvodí je prahování hranové reprezentace za účelem odstranění slabých hran a snížení počtu segmentů algoritmu rozvodí.


Druhý způsob spočívá v morfologických úpravách vstupního obrazu, jako je eroze, dilatace a rekonstrukce. Použitím těchto operací je možné zvýšit homogenitu oblastí obrazu, avšak za cenu posunu prahu jejich intenzit. Výsledky těchto operací jsou závislé na zvolených parametrech a rapidně se mění se změnou velikosti obrazu. Počet segmentů po aplikaci algoritmu rozvodí je stále vysoký, tudíž je po následné detekci hran nutnost odstranit znovu jejich nejslabší zástupce. V práci je tak použit první způsob zisku gradientního obrazu.

Výstupem dostupné funkce *watershed* v prostředí MATLAB je množství podoblastí. Pro každou z nich je vypočtena střední hodnota intenzity totožné oblasti v původním obrazu. Dle rozdělení intenzit v histogramu a experimentální zkušenosti jsou určeny intervaly, které rozlišují segmenty do tkáňových struktur WM, GM a CSF. V konečné fázi jsou odstraněny hranice mezi segmenty, které vznikly uplatněním metody rozvodí.

Mezi výhody této metody patří značná efektivita a spolehlivost segmentace, která je stabilní i při použití na silněji zašuměný obraz, avšak bez posunu prahu pro eliminaci slabých hran se vytváří větší počtu segmentů ke zpracování.



a) bez nastavení prahu



b) optimalizace počtu oblastí nastavením prahu
pro eliminaci slabých hran

Obr. 6.1: Oblasti po aplikaci metody rozvodí

7 HODNOTÍCÍ METODY

V této kapitole jsou uvedeny možnosti vzájemného hodnocení výsledků segmentace získané komerčním softwarem FreeSurfer s výsledky vlastních realizací. Srovnání výsledků bývá nedílnou součástí libovolné segmentace, nejinak tomu je v tomto případě. Přesnost jednotlivých segmentačních metod je často demonstrována na souborech obrazů, ke kterým existují správné referenční segmentace (tzv. zlatý standard), které jsou často tvořeny manuálně. Pro účel našeho hodnocení však budeme uvažovat výstupy programu FreeSurfer jako referenční. Navrženou metodikou je možné vybrat z realizovaných metod tu, která dosahuje lepších výsledků.

Pro účel komplexnějšího hodnocení výsledků bylo v programu MATLAB vytvořeno grafické uživatelské prostředí, jenž umožňuje prohlížení segmentovaných dat v celém svém rozsahu na základě výstupů z hlavního skriptu realizace. Uživatelské prostředí tak spojuje výhody vizuálního porovnání výsledků s aktuálními hodnotami srovnávacích koeficientů pro aktuální obrazový snímek, ale i v rámci celého zdrojového souboru.

Funkce prohlížeče je závislá na přítomnosti souborů s výsledky, které jsou generovány a ukládány do adresáře se zdrojovými soubory. Prohlížeč samotný neslouží k segmentaci. Jeho ovládání je jednoduché, stačí zvolit soubor, pro nějž chceme výsledek vykreslit a aplikovanou metodu. Poté stačí pouze posouvat posuvníkem mezi jednotlivými řezy obrazu.

7.1 Matematické hodnocení

Všechny srovnávací parametry zde uvedené jsou vypočteny podle stejného klíče. Pouze pokud je pro daný obrazový snímek a typ tkáně k dispozici segment nenulové velikosti stejně jako pro referenční segmentaci tkáně, jsou poté srovnávací parametry vypočteny. Pokud je jedna ze srovnávaných segmentací prázdná, parametry se nepočítají. Eliminujeme tím tak počet vzniklých chyb a jako výsledky porovnání dostaneme pouze smysluplné hodnoty rozdílů mezi vzniklými segmenty.

7.1.1 Rozhodovací klasifikátory

Porovnání získaných segmentů probíhá bod po bodu ve vztahu k referenčním rozdělením. Jak je možné vidět v *Tab. 7.1.*, při srovnávání je získáván pro každou jednotlivou realizaci segmentace počet správně pozitivních (TP), falešně pozitivních (FP), správně negativních (TN) a falešně negativních (FN) bodů mezi získanými a referenčními oblastmi. Při znalosti konečného počtu bodů ve všech klasifikovaných skupinách je možné přistoupit k výpočtu srovnávacích koeficientů. Ke zlepšení jejich interpretace je nastaveno pozadí pro

klasifikaci segmentů na oblast příslušící velikosti mozkové tkáně aktuálního zdrojového souboru. Znamená to tedy, že v rámci jednoho výstupu segmentace jsou jako tkáň označovány oblasti detekované jako segment, jako pozadí jsou označovány oblasti zbylé mozkové tkáně (nenulové oblasti zdrojového obrazu), které nejsou označeny jako tkáň.

		Referenční výsledky	
		Tkáň	Pozadí
Vlastní výsledky	Klasifikace tkáně	TP	FP
	Klasifikace pozadí	FN	TN

Tab. 7.1: Kontingenční tabulka klasifikace obrazových bodů

- TP (*true positive*) – body segmentu tkáně, které jsou reálně tkání,
- FP (*false positive*) – body mimo segment, které jsou reálně tkání,
- TN (*true negative*) – body mimo segment, které nejsou reálně tkání,
- FN (*false negative*) – body segmentu tkáně, které nejsou reálně tkání.

Senzitivita (TPR), neboli míra pravdivé positivity, určuje pravděpodobnost pozitivního označení pixelu jako tkáně (0 – 1), pokud je referenční pixel označen jako tkáň. Míra pravdivé negativity, tedy specifická (TNR), udává pravděpodobnost, kdy je skutečný pixel pozadí klasifikován jako pozadí (0 – 1). Senzitivitu a specificku je možné vypočítat:

$$TPR = \frac{TP}{TP + FN}, \quad (7.1)$$

$$TNR = \frac{TN}{TN + FP}. \quad (7.2)$$

Další možnost porovnání výsledků nabízí vyjádření koeficientu celkové správné klasifikace pixelů tkáně (ACC) nebo celkové nesprávné klasifikace pixelů (ERR). Koeficient správnosti nabývá ideálně 1 a chybovost 0 podle vztahů:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (7.3)$$

$$ERR = \frac{FP + FN}{TP + TN + FP + FN}, \quad (7.4)$$

$$ACC = 1 - ERR. \quad (7.5)$$

Ke srovnání výsledků je využito především Jaccardova koeficientu podobnosti, který vyjadřuje maximální podobnost pro dvojice shodných hodnot. Jinými slovy nabývá nulové hodnoty, pokud oblasti nemají žádné společné členy. Nezáleží přitom na tom, zda jsou identické svou velikostí. Maximální hodnota koeficientu nabývá 1. Použití tohoto indexu k hodnocení shody výsledků je obzvláště pro segmentace mozkových tkání časté. Koeficient získáme podle:

$$JC = \frac{TP}{TP + FP + FN} \cdot \quad (7.6)$$

7.1.2 Určení obsahu segmentů

Jinou možnou metodu porovnání výsledků představuje výpočet absolutního rozdílu velikosti vlastního segmentu a velikosti referenční oblasti a jeho poměru vůči referenční oblasti. Jeho hodnota udává absolutní poměr mezi velikostí obsahu vlastních a referenčních segmentací, jeho hodnoty tedy mohou přesáhnout hranici sta procent:

$$ERR_{obsah} = 100 \cdot \frac{|A_{ref} - A_{vlast}|}{A_{ref}} \cdot \quad (7.7)$$

7.2 Vizuální hodnocení

7.2.1 Překrytí obrazu jeho segmenty

Do základní vrstvy je zvolen původní obraz, který je v místech výskytu konečného segmentu nahrazen maximální intenzitou pixelu, tedy bílou barvou. Tento postup dodává posuzování výsledků lepší orientaci v souvislosti se zdrojovým souborem než uvedení pouze binárního obrazu vzniklých segmentů. Nevýhodou tohoto řešení je ztráta informace o podobě původního obrazu překrytého oblastí. Následující přístup situaci kompenzuje.

7.2.2 Překrytí obrazu konturami segmentů

Tento postup realizuje překrytí původního obrazu hranicemi segmentů (konturami), což dovoluje lépe porovnávat a hodnotit výsledky segmentačních postupů v souvislosti s referenčními. Lze taktéž dobře hodnotit závislosti na původním vstupním obrazu MR, který je důležitým prvkem samotného hodnocení pro posouzení nároků na korektní segmentaci – zlatý standard. V obrazu jsou prezentovány vždy dvě kontury – hranice referenční segmentace jsou obarveny červeně, vlastní segmentace metodou narůstání oblastí žlutě, metodou rozvodí pak modře.

8 VÝSLEDKY A HODNOCENÍ

Na tomto místě jsou uvedeny všechny výsledky srovnávání realizovaných segmentačních postupů s referenčními výsledky programu FreeSurfer. Prezentace výsledků se snaží kromě stanovení účinnější a přesnější segmentační metody zohlednit také způsob aplikace těchto metod. Konkrétně zda vykazují významně rozdílných výsledků při postupu 3D souborem dat MR po jednotlivých dvojrozměrných snímcích v koronární (CO), axiální (AX) či sagitální (SA) rovině. Představeny jsou hodnoty srovnávacích ukazatelů pro použité soubory (Tab. 8.1 až 8.3). Dále jsou uvedeny obrazové výstupy realizovaných segmentací (Obr. 8.1 až 8.3).

soubor	tkáň	metoda	rovina	TPR	TNR	ERR	JC	ERRobsah [%]
508	WM	RG	co	0,7618	0,9766	0,0888	0,7065	37,4
			ax	0,7787	0,9198	0,1332	0,6448	254,6
			sa	0,7556	0,9759	0,0918	0,6948	82,8
			prům.	0,7654	0,9574	0,1046	0,6820	124,9
		WS	co	0,7751	0,9507	0,0990	0,6888	22,0
			ax	0,8151	0,9485	0,0881	0,6686	53,5
			sa	0,7635	0,9466	0,1041	0,6668	22,3
			prům.	0,7846	0,9486	0,0971	0,6747	32,6
	GM	RG	co	0,6174	0,8499	0,2325	0,4902	50,4
			ax	0,6320	0,8404	0,2284	0,5052	19,8
			sa	0,6468	0,8124	0,2536	0,4905	404,7
			prům.	0,6321	0,8342	0,2382	0,4953	158,3
		WS	co	0,5831	0,8398	0,2471	0,4549	14,8
			ax	0,6155	0,8199	0,2452	0,4782	16,6
			sa	0,6135	0,8209	0,2572	0,4564	185,0
			prům.	0,6040	0,8269	0,2498	0,4632	72,1
	CSF	RG	co	0,6786	0,8553	0,1500	0,1388	3488,9
			ax	0,6378	0,8583	0,1466	0,1272	2305,6
			sa	0,6987	0,8530	0,1508	0,1529	1887,4
			prům.	0,6717	0,8555	0,1491	0,1396	2560,6
		WS	co	0,7055	0,9035	0,1016	0,1847	1902,7
			ax	0,6025	0,9204	0,0852	0,1659	1083,2
			sa	0,6744	0,9047	0,1014	0,1984	1281,3
			prům.	0,6608	0,9095	0,0961	0,1830	1422,4

Tab. 8.1: Kompletní srovnání výsledků segmentací prvního zdrojového souboru vůči referenčním výsledkům programu FreeSurfer

soubor	tkáň	metoda	rovina	TPR	TNR	ERR	JC	ERRobsah [%]
512	WM	RG	co	0,9104	0,6955	0,2626	0,4788	736,9
			ax	0,8124	0,8854	0,1270	0,5513	154,1
			sa	0,8086	0,8870	0,1268	0,6000	122,8
			prům.	0,8438	0,8226	0,1721	0,5434	337,9
		WS	co	0,8454	0,9165	0,0986	0,6126	110,3
			ax	0,8155	0,9196	0,0966	0,5917	121,4
			sa	0,7745	0,9231	0,1005	0,6101	31,3
			prům.	0,8118	0,9197	0,0986	0,6048	87,7
	GM	RG	co	0,5623	0,7826	0,3039	0,4187	34,3
			ax	0,5869	0,8109	0,2933	0,4531	36,3
			sa	0,6260	0,7705	0,2954	0,4515	108,5
			prům.	0,5917	0,7880	0,2975	0,4411	59,7
		WS	co	0,5169	0,8073	0,3032	0,3831	29,4
			ax	0,5337	0,8108	0,2877	0,4087	30,6
			sa	0,5379	0,8180	0,2869	0,4098	32,7
			prům.	0,5295	0,8120	0,2926	0,4005	30,9
	CSF	RG	co	0,7459	0,7512	0,2498	0,1162	5772,0
			ax	0,6729	0,7746	0,2293	0,1144	2859,3
			sa	0,6656	0,8121	0,1915	0,1318	987,6
			prům.	0,6948	0,7793	0,2235	0,1208	3206,3
		WS	co	0,6868	0,8728	0,1338	0,1791	2242,2
			ax	0,6486	0,8752	0,1308	0,1603	987,0
			sa	0,6787	0,8821	0,1247	0,1891	596,8
			prům.	0,6714	0,8767	0,1298	0,1762	1275,3

Tab. 8.2: Kompletní srovnání výsledků segmentací druhého zdrojového souboru vůči referenčním výsledkům programu FreeSurfer

Při hodnocení se zaměříme se zejména na výsledky Jaccardova koeficientu (JC) a celkové správné klasifikace pozadí (ERR), dále pak na senzitivitu a specificitu. Procentuální vyjádření chyby velikosti segmentů (ERRobsah) zde slouží jako doplňkový ukazatel a korektněji působí ve spojení s jednotlivými 2D obrazovými snímky při jejich prohlížení.

Detekce bílé hmoty mozkové vykazuje v souhrnu obou metod srovnatelné výsledky. V případě prvního souboru je JC pro narůstání oblastí (RG) nepatrně vyšší než pro algoritmus rozvodí (WS), v případě druhého souboru má vykazuje lepší podobnost segmentů naopak WS. Také výsledky dalších souborů nemluví jednoznačně. Celková správná klasifikace ERR nabývá pro oba soubory lepší hodnoty v rámci WS segmentace, k čemuž se připojuje vyšší senzitivita a nižší specificita oproti RG. V rámci hodnocení vůči referenčním výsledkům vykazují obě metody vysoký stupeň podobnosti. Největší rozdíly panují v oblasti mozkového


kmene, který má vůči ostatní bílé hmotě odlišné parametry. Také v dislokovaných a malých oblastech WM nejsou často segmenty zaznamenány. K tomu přispívá nastavené kritérium minimální velikosti oblasti patřící segmentu na 6 obrazových bodů, což platí stejně i pro segmenty ostatních tkáňových struktur. Přesnější segmentace bílé hmoty poskytují metody při použití v koronární či sagitální rovině.

Pro segmentaci šedé hmoty je srovnání lepší u metody narůstání oblastí a to takřka ve všech souborech u parametrů JC, TPR i TNR, kromě ERR, který hovoří spíše ve prospěch metody rozvodí. Segmentace GM je velmi náročná na přesnost a způsob postupu dané metody vzhledem k velké variabilitě kortikálních oblastí mozku. Lepší výsledky se vykazují při průchodu axiální nebo sagitální rovinou.


Vzhledem k referenčním segmentacím programu FreeSurfer, které obsahují segmenty mozkomíšního moku pouze v oblastech mozkových komor, je hodnocení výsledků realizací vůči nim problematické. Uplatněné realizace totiž k segmentu CSF přiřazují také likvor v subarachnoidální oblasti. Místy může docházet ke spojení oblastí CSF s GM vlivem menšího rozdílu mezi tkáněmi. Srovnání metod RG a WS ukazuje ve prospěch metody rozvodí, která produkuje méně segmentů mimo prostor mozkových komor. Výsledky segmentací jsou blíže referenčním při aplikaci na obrazy v koronární a sagitální rovině.

soubor	tkáň	metoda	TPR	TNR	ERR	JC	ERRobsah [%]
518	WM	RG	0,8381	0,9064	0,1132	0,6861	64,7
		WS	0,8028	0,9428	0,0904	0,6916	22,9
	GM	RG	0,5920	0,8559	0,2470	0,4830	73,2
		WS	0,5809	0,8725	0,2373	0,4813	29,0
	CSF	RG	0,6913	0,8234	0,1806	0,1309	2200,6
		WS	0,7007	0,8902	0,1144	0,1727	1301,9
524	WM	RG	0,7673	0,9752	0,0908	0,7150	35,7
		WS	0,7861	0,9637	0,0941	0,7223	16,6
	GM	RG	0,5728	0,8348	0,2501	0,4380	39,3
		WS	0,5739	0,8763	0,2196	0,4593	22,9
	CSF	RG	0,6134	0,7980	0,2058	0,0880	3111,3
		WS	0,6425	0,8850	0,1202	0,1374	1537,4
532	WM	RG	0,8102	0,9189	0,1118	0,6786	58,4
		WS	0,7988	0,9406	0,0934	0,6904	24,7
	GM	RG	0,5781	0,8098	0,2687	0,4345	72,8
		WS	0,5657	0,8314	0,2554	0,4271	24,8
	CSF	RG	0,6268	0,8264	0,1782	0,0937	3305,5
		WS	0,6346	0,9029	0,1027	0,1420	1665,7

Tab. 8.3 Celkové srovnání výsledků segmentací dalších zdrojových souborů vůči referenčním




a) metoda RG (žlutě) a referenční (červeně)




b) metoda WS (modře) a referenční (červeně)



c) původní obraz a WM pomocí RG (bíle)




d) původní obraz a WM pomocí WS (bíle)




e) původní obraz a referenční oblast WM (bíle)


Obr. 8.1: Výsledky segmentace bílé hmoty mozkové na koronárním řezu dat MRI




a) metoda RG (žlutě) a referenční (červeně)




b) metoda WS (modře) a referenční (červeně)



c) původní obraz a GM pomocí RG (bíle)




d) původní obraz a GM pomocí WS (bíle)




e) původní obraz a referenční oblast GM (bíle)


Obr. 8.2: Výsledky segmentace šedé hmoty mozkové na koronárním řezu dat MRI




a) metoda RG (žlutě) a referenční (červeně)




b) metoda WS (modře) a referenční (červeně)



c) původní obraz a CSF pomocí RG (bíle)



d) původní obraz a CSF pomocí WS (bíle)



e) původní obraz a referenční oblast CSF (bíle)

Obr. 8.3: Výsledky segmentace mozkomíšního moku na koronárním řezu dat MRI

9 ZÁVĚR

Jednou ze základních operací při zpracování obrazových dat je segmentace obrazu do jednotlivých zájmových oblastí. V práci byly popsány teoretické principy rozličných technik obrazové segmentace společně s popisem jejich vlastností a možným uplatněním na řešení zadání. Jedním ze sofistikovaných softwarových vybavení je program FreeSurfer, který byl spolu s dalšími komerčně dostupnými segmentačními programy jako 3D Slicer, Analyze, EIKONA3D, FSL, ITK a SPM popsán v této práci. K lepší orientaci v problematice rozdělení mozku na tkáňové struktury bílé a šedé hmoty a mozkomíšního moku byly uvedeny jejich základní vlastnosti a organizace mozku jako celku.

Součástí práce byl výběr vhodného zdroje obrazových dat bez výskytu abnormalit, lézí či nádorů k praktické realizaci. Byla vybrána T1-vážená MRI data předzpracovaná softwarem FreeSurfer, který byl uplatněn také na jejich finální segmentaci. Tato data posloužila jako reference k vlastním realizacím segmentačních technik narůstání oblastí (*region growing*) a rozvodí (*watershed*).

Metoda narůstání oblastí byla aplikována na zdrojový obraz s definovaným startovacím bodem, jehož poloha byla získána z předchozí analýzy tohoto obrazu. Zvětšování oblasti o nové členy bylo navrženo do osminásobného okolí hraničních bodů s lepšími výsledky než při čtyř okolí. Bylo nastaveno kritérium rozdílu intenzity pro začlenění bodů do segmentu vůči střední hodnotě intenzity dosavadní oblasti. Ač je postup metody časově a výpočetně náročný, bylo snahou redukovat tuto skutečnost snížením počtu startovacích bodů po každém uplatnění algoritmu. Byla rovněž testována jeho odolnost vůči přidanému šumu. Výsledky algoritmu byly i poté na dobré úrovni, avšak mohl se zvýšit počet nutných iterací. Při zvolené filtraci obrazu mediánovým typem filtru se projevilo zjemněním obrazu na rozhraní tkání, což bylo místy příčinou prolnutí segmentu do jiné zájmové oblasti obrazu. Ke zlepšení metody by bylo možné realizovat propracovanější výběr startovacích bodů a zvýraznit rozdíly mezi hledanými strukturami. Aplikace metody v trojrozměrném prostoru namísto samostatných 2D snímků je také místem k jejímu zdokonalení.

Pro metodu rozvodí byl zvolen postup detekce hran ze zdrojového obrazu v horizontálním i vertikálním směru, k čemuž byl vybrán Sobelův operátor poskytující spolehlivé výsledky i při aditivním zašumění obrazu. Snížení celkového počtu vnikajících oblastí bylo provedeno prahováním hranové reprezentace obrazu potlačením slabých hran. Vniklé podoblasti byly rozřazeny do tkáňových struktur na základě střední hodnoty intenzity každé z oblastí v původním obrazu. Zdokonalení postupu by žádalo propracovanější volbu prahu pro potlačení slabých hran některou z adaptivních metod a také pokročilejší postup při spojování dílčích podoblastí do vlastních tkáňových segmentů.

Důležitým aspektem práce byla srovnávací metodika, která dává výsledky realizací do souvislostí a umožňuje stanovit metodu, která je ve své podobě nejbližší referenčním výsledkům. Výsledky segmentace bílé hmoty mozkové odpovídaly dle zvolené metodiky referenčnímu rozdělení tkáně nejpřesněji, a to jak pro postup narůstáním oblastí, tak rozvodím. Přesnost rozdělení šedé hmoty je pro obě použité metody výrazně nižší, zhoršení všech srovnávacích parametrů se pohybuje v rozmezí 15 – 20 % oproti detekci WM. Lepších výsledků zde dosahuje metoda narůstání oblastí. Hodnocení oblastí mozkomíšního moku je obtížné vlivem vzniku segmentů, které referenční data neobsahují. Mezi metodami byl při segmentaci CSF úspěšnější postup rozvodí díky menšímu počtu segmentů mimo referenční oblasti. Prostorem ke zlepšení je odstranění takto detekovaných oblastí, které neodpovídají referenčním, z výstupních segmentů.

Dle vizuálního hodnocení dával postup RG přesnější výsledky, i pokud se hledané struktury vyskytovaly v menších oblastech. Vlivem nehomogenit větších oblastí je možné při tomto postupu nalézt nedetekované oblasti. Redukcí kritéria přiřazování bodů do segmentu, popřípadě filtrací obrazu bylo možné tento jev částečně potlačit, avšak za cenu dalších kompenzací. Metoda rozvodí naopak nalézala lépe větší oblasti, avšak na členitějších segmentech působila s menší přesností.

Cílem práce nebylo vnést zásadní myšlenku do problematiky obrazové segmentace, ale vytvořit a aplikovat metody segmentace, které po nastavení úvodních parametrů probíhají automaticky na jednotlivých 2D obrazech. Rozvoj řešení spočíval v aplikaci základních postupů v rozsahu celých souborů dat pořízených tomografem magnetické rezonance. Využitelnost a uplatnění výstupů práce nelze hledat při řešení náročných lékařských úkolů, jako se požaduje po sofistikovaných nástrojích, ale pro bližší pochopení souvislostí s těmito úkoly spojenými. Veškerá programová část práce byla realizována v programovém prostředí MATLAB.

LITERATURA

- [1] EVANS. A., C., et al. The NIH MRI Study of Normal Brain Development. In *NeuroImage*. 2006. vol. 30 (1), s. 184-202, ISSN 1053-8119.
- [2] DALE, A. M., FISHL, B., SERENO, M. I. Cortical surface-based analysis - I. Segmentation and surface reconstruction. In *NeuroImage*. 1999. vol. 9 (2), s. 179-194.
- [3] SABUNCU, M. R., et al. The Dynamics of Cortical and Hippocampal Atrophy in Alzheimer Disease. In *Archives of Neurology*. 2011. vol. 68 (8).
- [4] KUPERBERG, G. R., et al. Regionally Localized Thinning of The Cerebral Cortex in Schizophrenia. In *Archives of General Psychiatry*. 2003. vol. 60, s. 878-888.
- [5] SAILER, M., et al. Focal Thinning of the Cerebral Cortex in Multiple Sclerosis. In *Brain*. 2003. vol. 126 (9), s. 1734-1744.
- [6] CAI H., et al. Probabilistic Segmentation of Brain Tumors Based on Multi-Modality Magnetic Resonance Images. In *Biomedical Imaging: From Nano to Macro. 4th IEEE International Symposium 12-15 April, 2007*. 2007. s. 600-603.
- [7] JAN, J. *Medical Image Processing, Reconstruction and Restoration – Concepts and Methods*. Boca Raton : CRC Press, Taylor & Francis Group, 2005. s. 730. ISBN 0-8247-5849-8.
- [8] SONKA, M., HLAVAC, V., BOYLE, R. *Image Processing, Analysis, and Machine Vision*. Toronto : Thomson Learning, 2008. ISBN 0-495-24438-4.
- [9] ŠPANĚL, M., BERAN, V. Obrazové segmentační techniky. *Vysoké učení technické v Brně* [online]. poslední revize 19.ledna 2006. [citováno 20.dubna 2012]. <<http://www.fit.vutbr.cz/~spanel/segmentace/en>>.
- [10] KELBEL, J., ŠILHÁN, D. Shluková analýza. *Laboratoř biokybernetiky* [online]. poslední revize 19.října 2005. [citováno 20.dubna 2012]. <<http://www.gerstner.felk.cvut.cz/biolab/X33BMI/slides/KMeans.pdf>>.
- [11] KENNEDY, D. Center for Morphometric Analysis. *Internet Analysis Tools Registry* [online]. 2012. [citováno 10.dubna 2012]. <<http://www.cma.mgh.harvard.edu/iatr/>>.
- [12] NIH Blueprint for Neuroscience Research. *NITRC* [online]. Ver. 2.1.7-1. [citováno 10.dubna 2011]. <http://www.nitrc.org/search/?type_of_search=group>.
- [13] *3D Slicer* [online]. last revision April 2012. [citováno 20.dubna 2012]. <<http://www.slicer.org/>>.
- [14] *Biomedical Imaging: Riachard A. Robb – Analyze* [online]. last revision 2012. [citováno 10.dubna 2012]. <http://mayoresearch.mayo.edu/mayo/research/robb_lab/analyze.cfm>.
- [15] EIKONA3D. *Digital Image Processing Software* [online]. last revision 2005. [citováno 5.dubna 2012]. <<http://www.alphatecltd.com/eikona3d/imageprocessing3d.html>>.

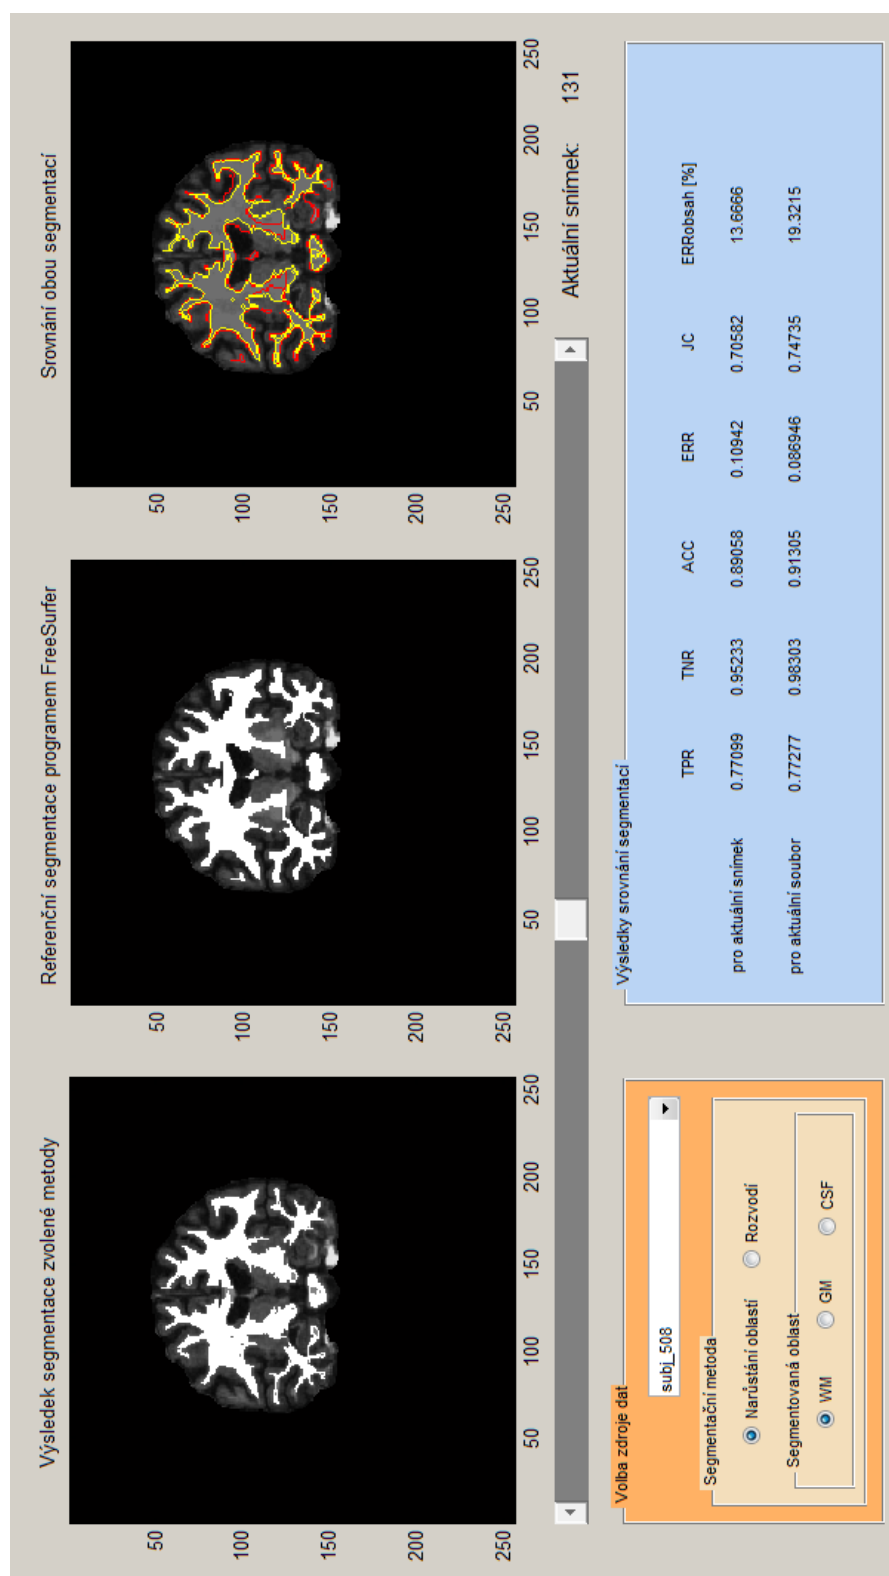
- [16] *Martinos Center for Biomedical Imaging* [online]. last revision 2005. [citováno 5.dubna 2012]. <<http://www.nmr.mgh.harvard.edu/martinos/flashHome.php>>.
- [17] *Talairach.org* [online]. last revision 2010. [citováno 5.dubna 2012]. <<http://www.talairach.org/>>.
- [18] *FreeSurferWiki* [online]. last revision 19th of March 2012. [citováno 5.dubna 2012]. <<http://surfer.nmr.mgh.harvard.edu/fswiki/Articles>>.
- [19] KOWKABZADEH, K. Chalmers University of Technology. *Evaluations of tissue segmentation of brain MR images* [online]. Master thesis. last revision 8th of October 2010. [citováno 15.března 2012]. <<http://publications.lib.chalmers.se/records/fulltext/125991.pdf>>. ISSN 99-2747920-4.
- [20] *FSL* [online]. last revision June 2008. [citováno 20.dubna 2012]. <<http://www.fmrib.ox.ac.uk/fsl/>>.
- [21] Atlases. *FSL* [online]. last revision June 2008. [citováno 20.dubna 2012]. <<http://www.fmrib.ox.ac.uk/fsl/data/atlas-descriptions.html#wm>>.
- [22] *ITK - Segmentation & Registration Toolkit* [online]. last revision 6th of March 2012. [citováno 5.dubna 2012]. <<http://www.itk.org>>.
- [23] *VTK - The Visualization Toolkit* [online]. last revision 29th of March 2012. [citováno 5.dubna 2012]. <<http://www.vtk.org/>>.
- [24] *Kitware Inc. – leading edge, high-quality software* [online]. last revision 29th of March 2012. [citováno 5.dubna 2012] <<http://www.kitware.com>>.
- [25] *SPM - Statistical Parametric Mapping* [online]. last revision 3rd of April 2012. [citováno 20.dubna 2012]. <<http://www.fil.ion.ucl.ac.uk/spm/>>.
- [26] *LONI / Atlases / Atlas Details* [online] last revision 2008. [citováno 20.dubna 2012]. <http://www.loni.ucla.edu/Atlases/Atlas_Detail.jsp?atlas_id=7>.
- [27] VADER, A. J., SHERMAN, J. H., LUCIANO, D. S. *Vanders's Human Physiology: The Mechanisms of Body Function*. 8th Edition. McGraw-Hill Education. 2001. ISBN 9780071180887.
- [28] NEUWIRTH, J. *Kompendium diagnostického zobrazování*. Praha : Triton, 1998. ISBN 80-85875-86-1.
- [29] SEIDL, Z a VANĚČKOVÁ, M. *Magnetická rezonance hlavy, mozku a páteře*. Praha : Grada Publishing, 2007. ISBN 978-80-247-1106-5.
- [30] YSTAD, M., et al. Cortico-striatal connectivity and cognition in normal aging: a combined DTI and resting state fMRI study. In *NeuroImage*. 2011. vol. 55 (1), s. 24-31.
- [31] YSTAD, M., et al. Subcortical functional connectivity and verbal episodic memory in healthy elderly: a resting state fMRI study. In *NeuroImage*. 2010. vol. 52 (1), s. 379-388.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

3D	Three-dimensional (trojrozměrný prostor) – podobně 1D a 2D
ACC	Accuracy (přesnost)
AIL	Artificial Intelligence Lab (Laboratoř umělé inteligence)
AX	Axial (axiální rovina)
CNS	Central Nervous System (centrální nervová soustava)
CO	Coronal (koronární rovina)
CSF	Cerebrospinal Fluid (mozkomíšní mok – likvor)
CT	Computed Tomography (výpočetní tomografie)
DTI	Diffusion Tensor Imaging (zobrazení tenzoru difuze)
EEG	Electroencephalography (elektroencefalografie)
ERR	Error (chyba)
FA	Flip Angle
fMRI	Functional Magnetic Resonance Imaging (zobrazování funkční magnetickou rezonancí)
FN	False Negative (falešně negativní)
FP	False Positive (falešně pozitivní)
FSE	Fast Spin Echo
FSPGR	Fast Spoiled Gradient Echo
GM	Gray Matter (šedá hmota mozková)
IATR	Internet Analysis Tools Registry (Internetový registr analytických nástrojů)
ICBM	International Consortium for Brain Mapping (Mezinárodního konsorcium pro mapování mozku)
ITK	Insight Segmentation and Registration Toolkit (Sada segmentačních a registračních nástrojů)
JC	Jaccard Coefficient (Jaccardův koeficient)
MGH	Massachusetts General Hospital (Všeobecná nemocnice v Massachusetts)

MIT	Massachussetts Institute of Technology (Massachusettský technologický institut)
MNI	Montreal Neurological Institute (Montrealský neurologický institut)
MR	Magnetic Resonance (magnetická rezonance)
MRI	Magnetic Resonance Imaging (zobrazování magnetickou rezonancí)
PD	Proton Density (hustota protonových jader)
PET	Positron Emission Tomography (pozitronová emisní tomografie)
RG	Region growing (narůstání oblastí)
SA	Sagital (sagitální rovina)
SNR	Signal to Noise Ratio (poměr signálu k šumu)
SPECT	Single Proton Emission Computed Tomography (jednofotonová emisní tomografie)
SPL	Surgical Plannig Lab (Laboratoř chirurgického plánování)
TE	Time Echo
TPM	Tissue Probability Maps (tkáňové pravděpodobnostní mapy)
TN	True Negative (správně negativní)
TNR	True Negative (míra pravdivé negativity)
TP	True Positive (správně pozitivní)
TPR	True Positive Rate (míra pravdivé positivity)
TR	Time to Repeat
VTK	Visualization Toolkit (Sada vizualizačních nástrojů)
WM	White matter (bílá hmota mozková)
WS	Watershed (rozvodí)

PŘÍLOHY



Obr. A: Celkový pohled na prohlížeč výsledků segmentace realizovaný v grafickém uživatelském prostředí programu MATLAB